

GWO with Santa-SSS ハイブリッドアルゴリズム

日大生産工 ○北村 達 日大生産工 山内 ゆかり

1. まえがき

数値シミュレーションや安定領域、データセットの分類など様々な最適化問題を解くメタヒューリスティックアルゴリズムが存在する。これらのアルゴリズムの中でも Grey Wolf Optimizer(GWO)はパラメータが少なく、原理が単純であるという利点があるが精度の不安定性と収束速度の遅さという問題点がある。

Yuxiang Houらは以上の問題を解決するために改良された GWO 最適化アルゴリズム (Improve Grey Wolf Optimization Algorithm and Application)[1]を提案した。改良型GWOでは初期化、収束係数、比例重みづけに着目し改良を図った。しかし、すべてのベンチマーク関数で最適解へ到達する学習は行えなかった。

本研究では、以上の問題において更なるパフォーマンス向上を図るために GWO with Santa-SSSのハイブリッドアルゴリズムを提案する。両者を組み合わせハイブリッドアルゴリズムで局所解への陥りを防ぎすべてのベンチマーク関数で最適解への到達を報告する。

2. 従来研究

2-1.GWO

GWOは2014年ハイイロオオカミの群れの捕食行動にヒントを得て、Seyed Mirjaliliらが提案した[2]。このアルゴリズムはハイイロオオカミをシミュレーションし各オオカミに役割を持たせタスクを遂行する。

GWOはオオカミを4つの社会階層に分類する。第一階層はオオカミ α で最も適合度が高いオオカミになる。オオカミ β はその次に高いオオカミで、 δ はその次である。それ以外をオオカミ ω とする。オオカミ ω を α 、 β 、 δ で更新し、その中で最も適合度が高いオオカミが次の α となる。これらを繰り返し最適解を求める。

$$D = |C * X_p(t) - X(t)| \quad (1)$$

$$X(t+1) = X_p(t) - A * D \quad (2)$$

X_p :獲物の座標

$X(t)$:ハイイロオオカミの座標

式(1)はオオカミと獲物との距離を示す。式(2)はハイイロオオカミの更新式を示す。パラメータ C 、 A は係数ベクトルであり、式(3),(4)に示す。

$$A = 2 * a * r_1 - a \quad (3)$$

$$C = 2 * r_2 \quad (4)$$

r_1, r_2 は $[0,1]$ の乱数でオオカミの動きを増加させる。 a は式(5)に示し、収束係数を表す。アルゴリズムが進むにつれ2から0に減衰し式(5)を定義する。

$$a = 2 - 2 * t / T_{max} \quad (5)$$

t :現在の反復回数

T_{max} :アルゴリズムの最大反復回数

$$D_\alpha = |C_1 * X_\alpha - X|$$

$$D_\beta = |C_2 * X_\beta - X| \quad (6)$$

$$D_\delta = |C_3 * X_\delta - X|$$

$$X_1 = |X_\alpha - A_1 * D_\alpha|$$

$$X_2 = |X_\beta - A_2 * D_\beta| \quad (7)$$

$$X_3 = |X_\delta - A_3 * D_\delta|$$

$$X(t+1) = (X_1 + X_2 + X_3) / 3 \quad (8)$$

式(6)は距離を示し、オオカミ δ は上位のオオカミを獲物とする。式(6)から式(7)を求め更新式(8)を定義する。

2-2.改良型GWO

改良型GWOでは初期化、収束係数、更新時の重みづけに着目した。初期化では多様性を持たせたいためなるべく均等に配置したい。これをカオス的に配置するとシロジスティックマッピングを行う。ロジスティックマッピングは非線形性、エルゴード性を持たせ局所最適に陥るのを防ぐ。初期化の式を(9),(10)に示す。

$$y_{i+1} = v * y_i + \frac{\text{rand}()}{N} \quad (9)$$

$$0 \leq y_i \leq 0.5$$

$$y_{i+1} = v * (1 - y_i) + \frac{\text{rand}()}{N} \quad (10)$$

$$0.5 \leq y_i \leq 1$$

v : $[0,2]$ の乱数を生成

y_i :初期の座標、 i はオオカミの個数

式(9),(10)は一つ前のオオカミの値によって初期化の式が変わる。それらは式下部の範囲に依存する。

収束係数は式(5)の収束係数を式(11)のようにガウス分布にすることで初期ではパラメータの減衰が遅く未知の大域領域に対する探索を行う。そうすることで大域領域の探索性能が向上し局所解に陥るのを防ぐ。

$$a = \frac{1}{\sqrt{2\pi} \left(\frac{T_{max}}{3}\right)} * e^{t^2/2 \left(\frac{T_{max}}{3}\right)^2} \quad (11)$$

比例重みづけは更新時に適合値によってどのオオカミの重要度が高いかを判断し、次のオオカミに反映させる。更新式を式(12)に示す。

$$\begin{aligned} W_{\alpha} &= (f_{\alpha} + f_{\beta} + f_{\omega})/f_{\alpha} \\ W_{\beta} &= (f_{\alpha} + f_{\beta} + f_{\omega})/f_{\beta} \\ W_{\omega} &= (f_{\alpha} + f_{\beta} + f_{\omega})/f_{\omega} \end{aligned} \quad (12)$$

$$\begin{aligned} V_1 &= (|X_1| + |X_2| + |X_3|)/|X_1| \\ V_2 &= (|X_1| + |X_2| + |X_3|)/|X_2| \\ V_3 &= (|X_1| + |X_2| + |X_3|)/|X_3| \end{aligned}$$

$$X(t+1) = (V_1 * W_{\alpha} + V_2 * W_{\beta} + V_3 * W_{\omega})/3$$

適合値 f がそれぞれの座標の重みになり適合値が良いものほど更新されるオオカミに影響するようになり、解の精度、収束の速度がともに向上する。Figure1に改良型GWOのフローチャートを示す。




Figure 1 改良型 GWO のフローチャート

3. 提案手法

Stochastic AnNealing Thermostats with Adaptive Moementum using Symmetric Splitting Scheme(Santa-SSS)[3]は確率的勾配マルコフ連鎖モンテカルロ (SG-MCMC) 手法にシミュレーテッドアニーリングを導入し、初期段階で多くのパラメータ空間を探索、絞り込みをして最適化を行うアルゴリズムである。シミュレーテッドアニーリングは焼きなまし法とも言われ、探索時はある一定のパラメータにも

依存するため局所解に陥りにくく、最適解まで探索が可能である。Santa-SSSはSG-MCMCという更新方式でパラメータの収束性を向上させ更なる効率化が見込める。

初期化はGWOのロジスティックマッピングな初期化を行い幅広い空間での初期化を行う。そのまま探索を行い、各ウルフの座標をSanta-SSSの初期値として扱う。その後シミュレーテッドアニーリングで探索範囲を狭めながら探索を行う。式(13)は更新式を示す。

$$U(0,1) > \exp\left(-\frac{\Delta E}{T}\right) \quad (13)$$

$U(0,1):[0,1]$ の一様分布

T :更新時に依存するパラメータ

ΔE :現在の位置と更新後の位置の差

U でのランダムなサンプリングで適合値が低くなった座標でもパラメータ T で悪い座標に更新する。これらを駆使し局所解への陥りを防ぐ。また、更新時はSG-MCMCを活用しパラメータの更新を効率化し収束を早める。

4. 実験および検討

ベンチマーク関数は改良型GWOで使われた関数10個で実験を行う。比較するアルゴリズムはGWO、改良型GWO、提案手法である改良型GWOにSanta-SSSを加えた3つのアルゴリズムで比較する。

5. まとめ

本研究では、GWOの収束速度と制度の不安定さに焦点を当て、Santa-SSSを導入することで以上の問題点が改善できると考える。今後は従来研究とともに、提案手法の実装に力を加えていく。

参考文献

- 1) Yuxiang Hou ,Huanbing Gao , ZijianWang and Chuansheng Du, "Improved Grey Wolf Optimization Algorithm and Application", Sensors 2022
- 2) Seyedali Mirjalilia, Seyed Mohammad Mirjalilib, Andrew Lewis, "Grey Wolf Optimizer",Crossmark (2014)
- 3) Changyou Chen,David Carlson, Zhe Gan, Chunyuan Li,Lawrence Carin, "Bridging the Gap between Stochastic Gradient MCMCand Stochastic Optimization",arxiv (2015)